

# SVM을 이용한 버터플라이 밸브의 캐비테이션 상태감시

## Cavitation Condition Monitoring of Butterfly Valve Using Support Vector Machine

황 원 우\* · 고 명 환\*\* · 양 보 석†

Won-Woo Hwang, Myong-Hwan Goh and Bo-Suk Yang

(2003년 9월 1일 접수 : 2003년 12월 29일 심사완료)

**Key Words** : Butterfly Valve(버터플라이밸브), Cavitation(캐비테이션), Condition Monitoring(상태감시), Kernel Function(커널함수), Sequence Minimize Optimization(SMO), Support Vector Machines(SVM)

### ABSTRACT

Butterfly valves are popularly used in service in the industrial and water works pipeline systems with large diameter because of its lightweight, simple structure and the rapidity of its manipulation. Sometimes cavitation can occur, resulting in noise, vibration and rapid deterioration of the valve trim, and do not allow further operation. Thus, the monitoring of cavitation is of economic interest and is very importance in industry. This paper proposes a condition monitoring scheme using statistical feature evaluation and support vector machine (SVM) to detect the cavitation conditions of butterfly valve which used as a flow control valve at the pumping stations. The stationary features of vibration signals are extracted from statistical moments. The SVMs are trained, and then classify normal and cavitation conditions of control valves. The SVMs with the reorganized feature vectors can distinguish the class of the untrained and untested data. The classification validity of this method is examined by various signals that are acquired from butterfly valves in the pumping stations and compared the classification success rate with those of self-organizing feature map neural network.

### 기 호 설 명

$b$	한계값(threshold value)
$E$	예측 오차
$K(\mathbf{x}, \mathbf{y})$	Kernel 함수( $= \phi(\mathbf{x}) = \phi(\mathbf{y})$ )
$L$	Lagrangian
$\mathbf{x}$	입력 벡터(input vector)
$(\mathbf{w}, \mathbf{x})$	벡터 $\mathbf{w}$ 와 $\mathbf{x}$ 의 내적
$\mathbf{w}$	가중치 벡터(weight vector)
$\ \mathbf{w}\ $	벡터 $\mathbf{w}$ 의 놈(norm)

$y_i$	출력 값 (+ 1 또는 1)
$\alpha$	Lagrange multipliers
$\phi(\mathbf{x})$	특징공간으로의 변환 함수
$\sigma$	RBF kernel의 폭(width)

### 1. 서 론

펌프장(pumping station)의 유량과 압력을 조절하기 위하여 펌프 토출측에 사용되고 있는 제어밸브(control valve)는 매우 중요한 밸브이다. 통상 제어밸브로는 버터플라이형, 볼형, 콘형 또는 편심플러그 형이 사용되며, 이 중 버터플라이밸브는 구조가 단순하고 가벼우며 가격이 저렴하고 제어특성도 우수하여 산업용 배관계통에 널리 사용되고 있다.

† 책임저자 : 정희원, 부경대학교 기계공학부  
E-mail : bsyang@pknu.ac.kr  
TEL : (051) 620-1604, FAX : (051) 620-1405  
\* 부경대학교 대학원 음향진동공학과  
\*\* 한국수자원공사 팔당권 관리단

유량제어밸브로 버터플라이밸브가 사용될 때, 밸브 개도(opening)가 낮은 범위에서는 종종 캐비테이션(cavitation) 현상이 발생한다. 유체가 배관을 통과할 때는 상대적으로 큰 단면적으로 인해 유속이 낮으나 밸브를 통과 시 유속은 급격히 증가하여 정압의 감소와 동압의 증가를 초래한다. 만일 유속이 한계유속 이상으로 크게 되면, 밸브시트에서의 압력이 액체의 포화증기압 이하로 떨어지고, 기포를 발생시킬 수 있다. 밸브를 통과한 유체의 압력은 포화증기압보다 훨씬 높게 되므로, 기포나 공동은 급격히 파괴된다. 기포가 파괴될 때, 모든 에너지는 매우 좁은 면적에 집중된다. 이는 좁은 면적에 엄청난 압력을 일으키고, 순간적인 충격파를 발생하게 된다. 이들 충격파가 밸브의 고체면에 충격을 가하고, 미소면 위의 반복된 기포의 파괴는 급속의 피로와 국부적인 침식(pitting)의 원인이 된다. 또한 캐비테이션은 진동과 소음을 일으키며, 밸브 트림(trim)의 급속한 열화를 야기시킨다.<sup>(1)</sup> 따라서, 밸브의 캐비테이션 발생유무를 감시하는 것은 펌프장의 안전 운영을 위해 매우 중요하다. 그러나 지금까지 캐비테이션 특성에 대한 연구는 비교적 많으나,<sup>(2)</sup> 발생감시에 대한 연구는 세계적으로 거의 없는 실정이다.

본 연구에서는 실제 광역상수도용 펌프장의 버터플라이 밸브에서 발생하는 캐비테이션의 상태감시를 위해 Support Vector Machine(SVM) 알고리즘을 이용한 상태감시시스템을 제안하고, 실제 밸브에 적용하여 그 유용성을 확인하였다.

## 2. 시험 설비

시험용 버터플라이밸브는 광역 상수도망의 상류 가압장으로부터 약 2 km 떨어진 곳에 위치하며, 폐쇄




Fig. 1 Cross-sectional view of a butterfly valve

상태에서 관로 압력 0.245 MPa, 구경 1,000 mm인 착수정용 유입밸브(inflow valve)이다. Fig. 1은 밸브의 개략도를 나타낸다. 이 밸브는 전동기로 구동되며, 디스크의 구동각도는 약 20~60도이다.

## 3. 데이터 취득 및 특징 추출

### 3.1 데이터 취득방법

밸브의 캐비테이션 진동을 측정하기 위하여 밸브 몸체에 수평 및 수직방향으로 가속도계를 설치하여 개도별(20%, 30%, 40%, 50%, 60%)로 5분간의 시간 데이터를 취득하여 레코더에 저장하였다. 측정된 진동신호의 주파수범위는 0~10 kHz이며, 샘플링 데이터수는 16,384개, 샘플링 시간은 0.05 ms이다. 진동측정에 사용된 가속도계는 압전소자형(piezoelectric compression type)이며, 측정감도는 100 mV/g, 주파수 영역은 5 Hz~15 kHz이다.

### 3.2 주파수 스펙트럼

Fig. 2는 밸브개도의 변화에 따른 수직방향 진동의 시간응답파형을 나타낸다. 40%의 개도에서 캐비테이션의 발생이 명확히 나타나고 개도를 줄일수록 진




Fig. 2 Time signal according to valve opening

폭은 급격히 증가하고 있다. Fig. 3는 밸브개도에 따라 발생한 수직 및 수평방향의 진동주파수 스펙트럼을 보여 주고 있다. 주파수분포의 중심대역은 수직방향 2.2 kHz, 수평방향 3.5 kHz로 밸브개도에 관계없이 일정하며, 밸브개도의 증가에 따라 그 값들이 크게 감소하여 캐비테이션이 발생하지 않는 50 % 이상에서는 진동이 거의 없음을 알 수 있다. 진폭이 큰 수직방향은 유체가 유동하는 방향으로 기포의 급격한 파괴로 인한 변동 유체력이 직접적으로 밸브시트에 작용하기 때문에 캐비테이션 발생여부를 파악하는데 수평방향보다 유리함을 알 수 있다.

### 3.3 통계적 특징 추출

센서로부터 취득된 시계열 신호는 시간상 연속적으로 취득된 것이 아니라 통계적인 표본 값이므로 시스템의 상태변화를 정확하게 표현하기 어렵다. 따라서 시계열 신호에 대하여 통계적인 처리기법을 이용하여

처리 분석하고 일정한 통계적 규칙을 갖고 있는 통계량으로 시계열 신호의 특징을 표현하여야 한다.<sup>(3)</sup>

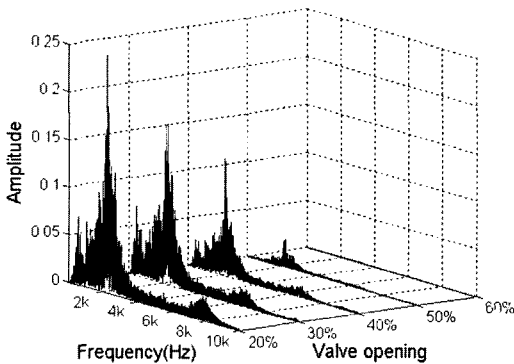
시계열 신호의 특징을 표현할 수 있는 파라미터는 여러 가지가 제안되어 있으나, 본 연구에서는 아래에 정의된 평균(mean), RMS(root mean square), 첨도(kurtosis) 및 형상계수(shape factor)를 사용하였다.

$$\text{Mean} : \mu = \frac{1}{N} \sum_{i=1}^N x_i$$

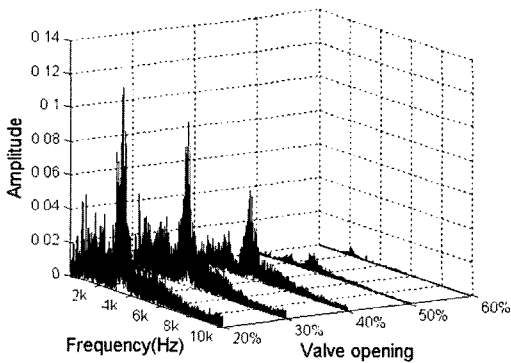
$$\text{RMS} : x_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$$

$$\text{kurtosis} : k = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^4}{\sigma^4}$$

$$\text{Shape factor} : s = x_{RMS} / \mu$$



(a) Vertical direction



(b) Horizontal direction

Fig. 3 Frequency spectrum according to valve opening

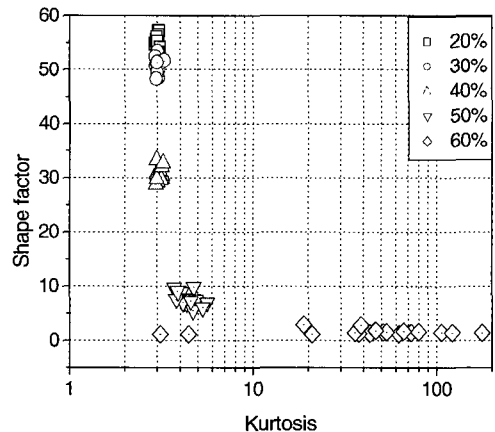
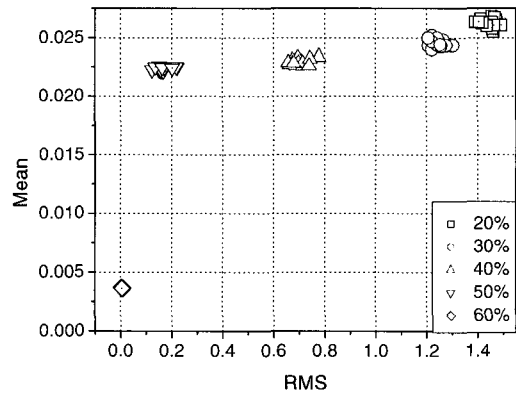


Fig. 4 Feature characteristics according to valve opening for vertical direction

여기서  $N$ 은 데이터 수이다.

Fig. 4는 수직방향의 진동신호에 대해 위에서 정의된 4가지 특징 파라미터에 대한 개도별 값들을 일 예로 도시하였다. 밸브 개도가 감소할수록 진동진폭의 평균과 RMS값이 크게 증가하고, 첨도는 Gaussian분포의 값인 3에 접근하는 것을 알 수 있다.

#### 4. SVM 알고리즘<sup>(4,5)</sup>

Support Vector Machine (SVM)의 이론은 1960년대 후반에 통계학적인 학습이론을 기초로 하여 Vapnik에 의해 처음 제안되었으나,<sup>(6)</sup> 당시 컴퓨터의 계산능력 부족으로 인해 1990년 중반에서야 다양한 분야에 적용되기 시작하였으며, 또한 현재 알고리즘의 성능향상을 위한 많은 연구가 이루어지고 있다.

기본적인 SVM은 이진 분류 문제에 널리 이용되며, hyperplane을 중심으로 한쪽은 positive 클래스, 다른 한쪽은 negative 클래스로 나눈다.  $(\mathbf{x}_i, y_i)$ ,  $(i=1, \dots, N)$ 를 훈련데이터 집합  $S$ , 데이터  $\mathbf{x}_i \in R^N$ 가 클래스  $y_i \in \{-1, 1\}$ 에 속한다고 하면, 두 데이터 집합의 경계가 되는 hyperplane은 식 (1)과 같이 정의된다.

$$\mathbf{w} \cdot \mathbf{x} + b = 0, \mathbf{w} \in R^N, b \in R \quad (1)$$

여기서,  $\mathbf{w}$ 는 두 데이터 집합의 경계가 되는 가중치벡터,  $\mathbf{x}$ 는  $N$ 차원의 입력벡터,  $b$ 는 한계값(thres-

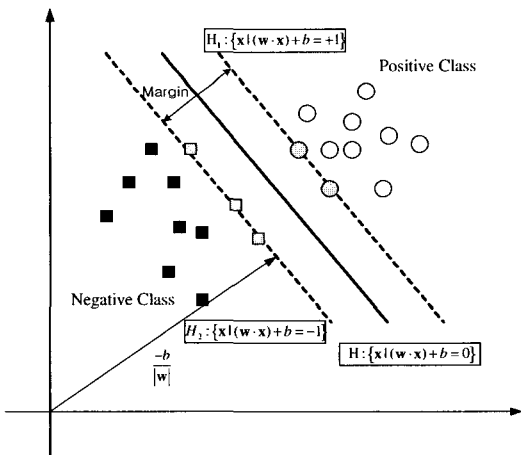


Fig. 5 Binary classification of dataset by SVM

hold value)이다.

Fig. 5는 다른 두 데이터 집합이 경계가 되는 hyperplane  $H$ 에 의해 분리되어짐을 보이고 있다. SVM은 경계와 각 클래스에 속한 가장 인접한 데이터와의 거리(margin)가 최대가 되게 한다. 그림에서 경계와 가장 인접한 회색의 원과 사각형 데이터 점을 support vector (SV)라 하며, 이 SV에는 두 클래스를 구분할 수 있는 모든 정보들이 포함되어 있기 때문에 이를 제외한 나머지 데이터는 필요 없게 되어 폐기된다. 따라서 데이터의 over-fitting과 테스트 시간이 상대적으로 모든 데이터를 사용하는 다른 알고리즘에 비하여 빠르게 된다. 새로운 데이터에 대한 결정함수(decision function)는 식 (2)와 같이 정의된다.

$$f(\mathbf{x}) = \text{sign}(\mathbf{w} \cdot \mathbf{x} + b) \quad (2)$$

두 hyperplane  $H_1$ 과  $H_2$  사이의 거리를 구하면 식 (3)과 같으며, 이 값이 최대가 되어야 한다.

$$\text{margin} = \frac{2}{\|\mathbf{w}\|} \quad (3)$$

식 (2)와 (3)을 정리하면 식 (4)와 같은 최적화문제에 귀착된다.

$$\begin{aligned} \text{Minimize } \tau(\mathbf{w}) &= 1/2\|\mathbf{w}\|^2 \\ \text{subject to} & \\ y_i(\mathbf{w} \cdot \mathbf{x}_i + b) &\geq 1, \quad i=1, 2, \dots, N \end{aligned} \quad (4)$$

식 (4)를 풀기 위하여 Lagrange multipliers  $\alpha_i \geq 0$  ( $i=1, 2, \dots, N$ )의 개념을 도입하면, Lagrangian은 식 (5)와 같이 된다.

$$L(\mathbf{w}, b, \boldsymbol{\alpha}) = \frac{1}{2}\|\mathbf{w}\|^2 - \sum_{i=1}^N \alpha_i y_i (\mathbf{w} \cdot \mathbf{x}_i - b) + \sum_{i=1}^N \alpha_i \quad (5)$$

여기서  $\frac{\partial L}{\partial \mathbf{w}} = 0, \frac{\partial L}{\partial b} = 0$ 이고, 이는 각각 다음과 같이 유도된다.

$$\mathbf{w} = \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i, \quad \sum_{i=1}^N \alpha_i y_i = 0 \quad (6)$$

식 (6)을 식 (5)에 대입하여 정리하면,

Maximize

$$L_D(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \mathbf{x}_i \cdot \mathbf{x}_j$$

Subject to

$$\alpha_i \geq 0, \quad i=1, 2, \dots, N,$$

$$\sum_{i=1}^N \alpha_i y_i = 0 \quad (7)$$

식 (7)로부터  $\alpha_i$ 를 구할 수 있으며, 이  $\alpha_i$ 를 식 (6)에 대입하여  $\mathbf{w}$ 를 구할 수 있다. 식 (6)을 사용하여 결정함수인 식 (2)를 재정의하면, 식 (8)과 같이 된다.

$$f(\mathbf{x}) = \text{sign} \left( \sum_{i=1}^N \alpha_i y_i (\mathbf{x}_i \cdot \mathbf{x}) + b \right) \quad (8)$$

따라서, 이제 한계값  $b$ 를 구하게 되면, 새로운 입력 데이터  $\mathbf{x}$ 를 분류할 수 있다. 여기서  $b$ 는 SVM의 학습 알고리즘으로 제안된 Sequence Minimize Optimization(SMO)<sup>(7,8)</sup>를 이용하여 구한다.

지금까지는 입력 공간이 선형적으로 분리가 가능한 경우만을 고려하였다. 그러나 실제로 많은 경우가 선형적으로 두 클래스를 구별할 수 없다. 하지만  $N$  차원 입력공간의 데이터를 고차원의 특징공간( $Q$  차원)으로 변환함으로써 선형적으로 구별할 수 있으며(Fig. 6), 이를 위해 kernel 함수를 이용한다.

변환함수는 식 (9)와 같이 정의된다.

$$\mathbf{s} = \Phi(\mathbf{x}) \quad (9)$$

여기서,  $\mathbf{x} \in R^N$ ,  $\mathbf{s} \in R^Q$ 이다. 식 (9)를 결정함수인 식 (8)에 대입하면 다음과 같다.




Fig. 6 Transformation to linear feature space from nonlinear input space

$$f(\mathbf{x}) = \text{sign} \left( \sum_{i=1}^N \alpha_i y_i (\Phi(\mathbf{x}) \cdot \Phi(\mathbf{x}_i)) + b \right) \quad (10)$$

결정함수를 kernel함수  $K(\mathbf{x}, \mathbf{y}) = \Phi(\mathbf{x}) \cdot \Phi(\mathbf{y})$ 로 대체하면 식 (11)과 같이 된다.

$$f(\mathbf{x}) = \text{sign} \left( \sum_{i=1}^N \alpha_i y_i K(\mathbf{x}, \mathbf{x}_i) + b \right) \quad (11)$$

따라서, 식 (11)을 통하여 SVM이 비선형적인 입력공간을 선형적인 특징공간으로 변환하여 분류할 수 있다. 일반적으로 사용되는 kernel함수로는 RBF kernel, polynomial kernel, perceptron, linear 등이 있으며, 여기에서는 주로 다음에 정의되는 RBF kernel을 사용한다.

$$K(x, y) = \exp \left( -\frac{\|x - y\|^2}{2\sigma^2} \right)$$

여기서, RBF kernel 파라미터  $\sigma$ 는 반복적인 방법의 수행을 통하여 구하였다.

## 5. SMO 알고리즘<sup>(7,8)</sup>

Sequence minimize optimization(SOM) 알고리즘은 SVM을 학습시키기 위해 기존의 분해법과 비슷한 방법으로 가능한 가장 작은 크기의 Quadratic Programming(QP) 문제로 나누어서 전체 QP 최적화 문제를 풀게 된다. SMO는 QP문제를 해석적인 방법으로 풀기 때문에 내부 루프로서 시간 소비적인 수치적 QP최적화를 수행하지 않는다. 또한 필요한 메모리의 크기도 학습 데이터의 크기에 따라 선형적으로 달라진다. 따라서 매우 방대한 양의 학습 데이터도 다룰 수 있고, 또한 학습에 소요되는 시간은 SVM의 결정함수를 평가하는데 지배되기 때문에 선형 SVM과 학습 데이터 양이 적은 경우에 적합하다.

### 5.1 Lagrange Multipliers $\alpha_i$ 의 최적화 과정

SMO 알고리즘은 목적함수를 최대화하는  $\alpha_i$ 를 구하는데 있어 한번에 두개의  $\alpha_i$ 값을 찾는다. 목적함수는 식 (12), 구속조건은 식 (13)과 같다.

$$L_D(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \mathbf{x}_i \cdot \mathbf{x}_j \quad (12)$$

$$\sum_{i=1}^N \alpha_i y_i = 0 \quad (13)$$

식 (13)의 조건을 이용하여  $\alpha_1, \alpha_2$  값을 제외한 나머지  $\alpha$  값은 임의의 값으로 고정시킨다. 그러면 식 (13)을 다음과 같이 쓸 수 있다.

$$y_1 \alpha_1 + y_2 \alpha_2 = y_1 \alpha_1^{\text{old}} + y_2 \alpha_2^{\text{old}} = \text{const} \quad (14)$$

Fig. 7은 식 (14)를 도식적으로 나타낸 것이다. 이는 경계구속을 나타내는 것으로  $\alpha_2$ 의 경계값은 다음과 같이 된다.

$$\begin{cases} L = \max(0, \alpha_2^{\text{old}} - \alpha_1^{\text{old}}) \\ H = \min(C, C + \alpha_2^{\text{old}} - \alpha_1^{\text{old}}) \end{cases} \text{ if } y_1 \neq y_2$$

$$\begin{cases} L = \max(0, \alpha_1^{\text{old}} + \alpha_2^{\text{old}} - C) \\ H = \min(C, \alpha_1^{\text{old}} + \alpha_2^{\text{old}}) \end{cases} \text{ if } y_1 = y_2 \quad (15)$$

목적함수를 풀어 쓰면

$$L_D(\alpha) = \alpha_1 + \alpha_2 + \text{const}$$


$$- \frac{1}{2} (y_1 y_1 \mathbf{x}_1^T \mathbf{x}_1 \alpha_1^2 + y_2 y_2 \mathbf{x}_2^T \mathbf{x}_2 \alpha_2^2$$

$$+ 2y_1 y_2 \mathbf{x}_1^T \mathbf{x}_2 \alpha_1 \alpha_2 + 2 \left( \sum_{i=3}^N \alpha_i y_i \mathbf{x}_i^T \right) (y_1 \mathbf{x}_1 \alpha_1 + y_2 \mathbf{x}_2 \alpha_2)$$

$$+ \text{const}) \quad (16)$$

식 (16)에서

$$v_j = \sum_{i=3}^N \alpha_i y_i \mathbf{x}_i^T \mathbf{x}_j$$



$$y_1 \neq y_2 \Rightarrow \alpha_1 - \alpha_2 = \gamma \quad y_1 = y_2 \Rightarrow \alpha_1 + \alpha_2 = \gamma$$

Fig. 7  $y_1 \alpha_1 + y_2 \alpha_2 = y_1 \alpha_1^{\text{old}} + y_2 \alpha_2^{\text{old}} = \text{const}$

$$= u_j^{\text{old}} + b^{\text{old}} - \alpha_1^{\text{old}} y_1 x_j^T x_j - \alpha_2^{\text{old}} y_2 x_2^T x_j$$

여기서,  $u_j^{\text{old}} = \mathbf{x}_j^T \mathbf{w}^{\text{old}} - b^{\text{old}}$ 이며,  $\mathbf{x}_j$ 의 결과 값이다.

$K_{11} = \mathbf{x}_1^T \mathbf{x}_1, K_{22} = \mathbf{x}_2^T \mathbf{x}_2, K_{12} = \mathbf{x}_1^T \mathbf{x}_2$  라 두면, 식 (16)은 다음과 같이 된다.

$$L_D(\alpha) = \alpha_1 + \alpha_2 - \frac{1}{2} (K_{11} \alpha_1^2 + K_{22} \alpha_2^2 + 2s K_{12} \alpha_1 \alpha_2$$

$$+ 2y_1 v_1 \alpha_1 + 2y_2 v_2 \alpha_2) + \text{const}$$

$$= \frac{1}{2} (2K_{12} - K_{11} - K_{22}) \alpha_2^2$$

$$+ (1-s + s K_{11} \gamma - s K_{12} \gamma + y_2 v_1 - y_2 v_2) \alpha_2$$

$$+ \text{const} \quad (17)$$

여기서  $\eta = 2K_{12} - K_{11} - K_{22}$ 라 두면,  $\alpha_2$ 의 계수는 다음과 같이 된다.

$$1-s + s K_{11} \gamma - s K_{12} \gamma + y_2 v_1 - y_2 v_2$$

$$= y_2 (E_1^{\text{old}} - E_2^{\text{old}}) - \eta \alpha_2^{\text{old}} \quad (18)$$

여기서  $E_i^{\text{old}} = u_i^{\text{old}} - y_i$  로써 예측오차이다.

식 (18)을 식 (17)에 대입하여 정리하면 식 (19)와 같이 된다.

$$L_D(\alpha) = \frac{1}{2} \eta \alpha_2^2 + (y_2 (E_1^{\text{old}} - E_2^{\text{old}}) - \eta \alpha_2^{\text{old}}) \alpha_2 + \text{const} \quad (19)$$

위 식을  $\alpha_2$ 에 대해 1계 및 2계 미분을 구하면 다음과 같다.

$$\frac{dL_D}{d\alpha_2} = \eta \alpha_2 + (y_2 (E_1^{\text{old}} - E_2^{\text{old}}) - \eta \alpha_2^{\text{old}})$$

$$\frac{d^2 L_D}{d\alpha_2^2} = \eta \quad (20)$$

여기서 목적함수가 최대값을 가지기 위해서는 1계 미분의 값이 0이어야 한다. 따라서,

$$\alpha_2^{\text{new}} = \alpha_2^{\text{old}} + \frac{y_2 (E_1^{\text{old}} - E_2^{\text{old}})}{\eta} \quad (21)$$

이 된다. 식 (15)의 경계값을 고려하면

$$\alpha_2^{new,clipped} = \begin{cases} H & \text{if } \alpha_2^{new} \geq H; \\ \alpha_2^{new} & \text{if } L < \alpha_2^{new} < H; \\ L & \text{if } \alpha_2^{new} \leq L; \end{cases} \quad (22)$$

그리고,

$$\alpha_1^{new} = \alpha_1^{old} + s(\alpha_2^{old} - \alpha_2^{new}) \quad (23)$$

### 5.2 한계값 $b$ 의 계산

예측오차  $E(\mathbf{x}, y)$ 와 예측오차의 변화량  $\Delta E(\mathbf{x}, y)$ 는 다음과 같다.

$$E(\mathbf{x}, y) = \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i^T \mathbf{x} - b - y$$

$$\Delta E(\mathbf{x}, y) = \Delta \alpha_1 y_1 \mathbf{x}_1^T \mathbf{x} + \Delta \alpha_2 y_2 \mathbf{x}_2^T \mathbf{x} - \Delta b$$

한계값  $b$ 는  $E(\mathbf{x}, y)^{new} = 0$ 일 때이므로, 식 (23)에 의하여 구하여 진다.

$$E(\mathbf{x}, y)^{new} = E(\mathbf{x}, y)^{old} + \Delta E(\mathbf{x}, y)$$

따라서,

$$\Delta b = E(\mathbf{x}, y)^{old} + \Delta \alpha_1 y_1 \mathbf{x}_1^T \mathbf{x} + \Delta \alpha_2 y_2 \mathbf{x}_2^T \mathbf{x}$$

가 된다.

## 6. 시스템의 구성 및 결과

### 6.1 상태분류시스템의 구성

Fig. 8은 캐비테이션의 발생 여부를 판별하기 위해 제안된 시스템의 흐름도를 보여주고 있다.

진동 계측기(DSP/AD board)를 통하여 취득한 시간 데이터에서 4가지의 특징 파라미터 값들을 각 개도별로 추출하여 학습 데이터로 저장된다. 이 학습 데이터를 SMO 알고리즘에 입력하여 SV를 구하며 나머지 학습 데이터는 폐기하여 새로운 SV들의 데이터베이스(DB)를 구성하게 된다. 이 DB는 진동 계측기로부터 취득한 새로운 데이터의 미지의 상태를 판별하기 위한 기초 데이터가 되며, 이 데이터를 이용한 SVM 알고리즘이 새로운 데이터에 대한 미지의

상태를 판별하게 된다.

### 6.2 데이터의 구성

SVM을 위한 학습과 테스트 데이터를 밸브개도별로 각각 70개씩 총 350개를 사용하였다. 이 중 100개는 학습데이터로, 나머지 250개는 테스트 데이터로 사용하였다. 각 데이터는 취득한 시간신호에서 앞에

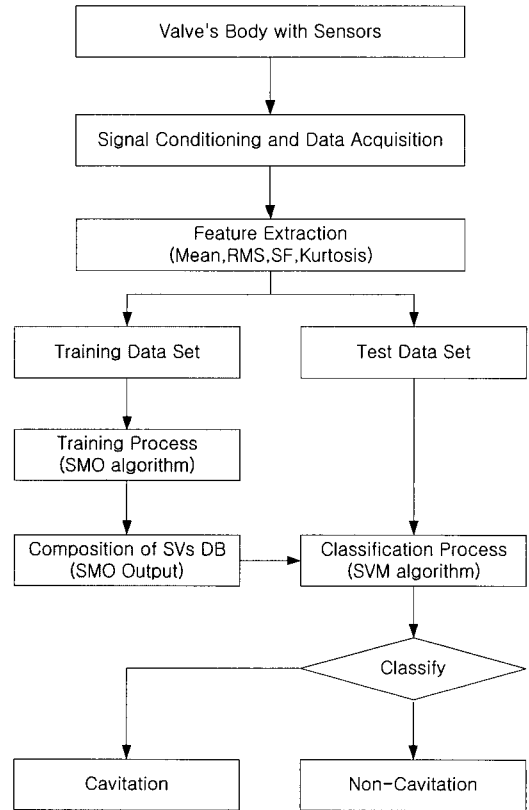


Fig. 8 Flow chart of classification system

Table 1 Composition for learning and test data

	Condition	Valve opening	Data No.
Learning data	Cavitation	20 %	20
		30 %	20
		40 %	20
	Normal	50 %	20
		60 %	20
Test data	Cavitation	20 %	50
		30 %	50
		40 %	50
	Normal	50 %	50
		60 %	50

서 언급한 4가지의 특징 파라미터들로 구성되어져 있다

### 6.3 학습 및 테스트 결과

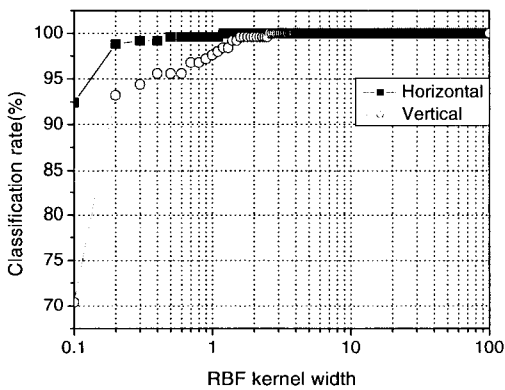
SVM에서 양호한 분류성능을 얻기 위해서는 RBF kernel 폭  $\sigma$ 의 결정이 매우 중요하다. 이 값은 다차원 특징공간에서 분류기 경계로서 데이터를 둘러싼 초구면(hypersphere)의 반경을 결정하기 때문이다. 이 값이 너무 작으면 둘러싼 특징공간 역시 매우 작아 데이터의 중요 부분을 놓치게 되고 불만족스러운 분류율을 초래할 수 있다. 역으로 너무 큰 값은 둘러싸는 특징공간이 크게 되고 클래스들이 서로 겹쳐 오 분류를 일으킬 가능성이 있다. 통상 전체 특징집합에 기초하여 반복적인 방법으로 최적의 값을 구한다. Fig. 9는 RBF kernel 폭  $\sigma$ 에 따른 분류율과 SV의 개수를 나타내고 있다. 그림에서 예로  $\sigma$ 가 0.1의 작

은 값을 취하면 분류 오차가 수직방향에서 29.6 %로 크게 되는 것을 알 수 있다. SV의 수는  $\sigma$ 의 증가에 따라 감소하다 다시 증가하는 경향을 가진다. 따라서  $\sigma$ 의 결정은 가장 좋은 분류율을 가지며 SV수가 가장 작은 경우의 값을 최적치로 선택한다. 이는 SV의 수가 작을 수록 테스트에 소요되는 시간이 작게 되기 때문이다.

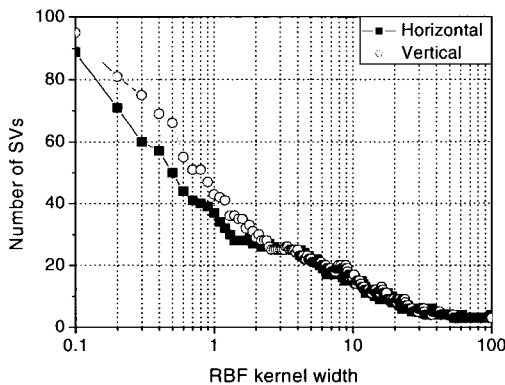
Table 2는 벨브의 수평 및 수직방향에 대하여 SVM과 자기조직화특징지도(SOFM) 신경망 알고리즘<sup>(3,9)</sup>의 분류율과 이 때 사용된 kernel폭 및 SV 수를 비교한 결과를 보여주고 있다. 여기서 SVM은 RBF kernel폭  $\sigma$ 를 Jack과 Nandi<sup>(10)</sup>가 제안한 평균폭(average width)을 이용한 경우와 반복과정을 통하여 최적값을 구한 일정 폭(constant width)을 이용한 경우를 비교하였다.

평균 폭의 계산방법은 입력벡터 내에 각 특징에 대해 주어진 클래스의 모든 값에 대한 표준편차를 이용하여 구한다.<sup>(10)</sup> 평균 폭 SVM과 Fig. 7로부터 구한 최적값을 이용한 일정 폭 SVM은 모두 각 방향에 대하여 학습(training) 및 테스트 모두 100 %의 양호한 분류결과를 얻었다. 그러나 SOFM은 학습에서는 모두 100 %의 양호한 분류율이 얻어지나 테스트에서는 수직 및 수평방향 각각 84.8 %, 87.2 %의 분류율이 얻어지고 있다.

Table 3은 5종류의 kernel함수에 대한 정의들, Table 4는 이들 함수에 따른 분류율과 SV 수를 나타내고 있다. 선형함수와 Gaussian RBF는 학습 및 테스트 모두 100 %의 양호한 분류율을 보이지만, 다항식(2차) 및 Laplacian RBF는 수직방향 신호에 대해서 분류가 되지 않고 있음을 알 수 있다. 일반적으



(a) Horizontal direction



(b) Vertical direction

Fig. 9 Estimation of RBF parameter

Table 2 Performance comparisons of classifier

Classifier	Direction	Classification rate (%)		RBF kernel width	Number of SVs
		Training	Testing		
SVM (average width)	Hori.	100	100	8.08	17
	Verti.	100	100	6.88	19
SVM (constant width)	Hori.	100	100	52.9	3 (opt.)
	Verti.	100	100	61.1	3 (opt.)
	Hori.	100	99.6	1.0	37
	Verti.	100	97.6	1.0	43
SOFM	Hori.	100	87.2	-	-
	Verti.	100	84.8	-	-



로 kernel함수의 선정은 사전에 결정하는 것이 불가능하므로 적절한 함수를 선정하는 것이 양호한 분류율을 얻기 위해서는 매우 중요함을 알 수 있다.

### 7. 결론

본 연구에서는 분류기로서 이진 분류에 뛰어난 SVM과 패턴분류에 널리 사용되는 SOFM신경망을 이용하여 버터플라이 밸브의 캐비테이션 발생 여부를 판별하는 감시시스템(monitring system)을 제안하였다. 진동 가속도신호의 정상 특징을 통계적 모멘트를 이용하여 특징을 추출하였으며, 이를 입력데이터로 하여 분류기를 훈련(학습)하고 밸브의 정상 및 캐비테이션 상태를 분류하였다. 실제 광역상수도 계통에 사용되는 대형 버터플라이 밸브로부터 신호를 취득하여 테스트한 결과, 제안된 시스템이 양호한 분류 성능을 가지고 캐비테이션을 탐지할 수 있음을 확인하였다. SVM의 분류 정도가 훈련 및 테스트 데이터 모두 100 %를 제공하고 SOFM보다 뛰어났다. 제안된 시스템은 밸브의 자동 상태감시 및 진단시스템과 실시간 실행을 가능하도록 함으로서 심각한 고장에 이르기 전에 문제를 사전에 탐지하고 즉시 보수작업의 스케줄을 설정하는데 크게 기여할 수 있을 것으로 기대된다.

**Table 3** Formulation for used kernel functions

Kernel	$K(\mathbf{x}, \mathbf{y})$
Linear	$\mathbf{x} \cdot \mathbf{y}$
Polynomial	$(\mathbf{x} \cdot \mathbf{y} + 1)^d$
Gaussian RBF	$\exp\{-\frac{1}{2\sigma^2}(\ \mathbf{x} - \mathbf{y}\ ^2)\}$
Laplacian RBF	$ \mathbf{x} - \mathbf{y} $
Chi square	$(\mathbf{x} - \mathbf{y})^2/(\mathbf{x} - \mathbf{y})$

**Table 4** Classification rate and number of SVs according to different kernel functions

Kernel	Classification rate (%)				Number of SVs	
	Training		Testing			
	Hor.	Ver.	Hor.	Ver.	Hor.	Ver.
Linear	100	100	100	100	2	2
Polynomial	97	0	99.6	0	2	-
Gaussian	100	100	100	100	3	2
Laplacian	20	0	0	20	80	80
Chi square	70	100	86	100	30	2

### 참고 문헌

- (1) Carlson, B., 2001, "Avoiding Cavitation in Control Valves," ASHRAE Journal, Vol. 43, No. 6, pp. 58~63.
- (2) Kimura, T., et al., 1995, "Hydrodynamic Characteristics of a Butterfly Valve- Prediction of Pressure Loss Characteristics," ISA Trans., Vol. 34, pp. 319~326.
- (3) 양보석, 서상윤, 임동수, 이수종, 2000, "자기조직화특징지도와 학습벡터양자화를 이용한 회진기계의 이상진동진단 알고리즘," 한국소음진동공학회논문집, 제 10 권, 제 2 호, pp. 331~337.
- (4) Hearst, M. A., Scholkopf, B., Dumais, S., Osuna, and E. Platt, J., 1998, "Trends and Controversies-support Vector Machines," IEEE Intelligent System, Vol. 13, No. 4, pp. 18~28.
- (5) Cristianini, N. and Taylor, J.S., 2000, "An Introduction to Support Vector Machines and Other Kernel-based Learning Methods," Cambridge University Press.
- (6) Vapnik, V. N., 1982, Estimation of Dependences Based on Empirical Data, Springer-verlag.
- (7) Platt, J., 1999, "Fast Training of Support Vector Machines using Sequential Minimal Optimization," In B. Scholkopf, C. J. C. Burges, A. J. Smola, "Advances in Kernel Methods-support Vector Learning," MIT Press, pp. 336~342.
- (8) Keerthi, S. S. and Shevade, S. K., 2002, "SMO Algorithm for Least Squares SVM Formulations," Control Division Technical Report CD-02-8.
- (9) Kohonen, T., 1996, "Engineering Application of the Self-organizing Feature Map," Proceeding of IEEE, Vol. 84, No. 10, pp. 1358~1384.
- (10) Jack, L. B. and Nandi, A. K., 2002, "Fault Detection using Support Vector Machines and Artificial Neural Networks, Augmented by Genetic Algorithms, Mechanical Systems and Signal Processing, Vol. 16, No. 2-3, pp. 373~390.